

基于改进 BP 神经网络收割机铆接接头力学性能预测

谢 威 季丹丹

牡丹江师范学院 黑龙江 牡丹江市

摘要: 针对收割机结构钢铝材料的铆接接头力学性能差和技术难度大问题, 使用改进的神经网络模型研究钣金结构厚度、硬度、接头底部直径等接头技术参数与材料自身剪切力与剥离力强度等力学参数的映射关系。结果表明, 训练后的神经网络模型能够准确有效地预测收割机铆接接头力学性能, 剪切强度最大相对误差从 % 下降到 %, 剥离强度相对误差从 % 下降到 %, 证实改进神经网络应用于收割机铆接接头力学性能预测的可行性与可靠性, 为收割机钢铝材料铆接接头设计提供参考依据。

关键词: 收割机 改进 神经网络 铆接接头 力学性能

中图分类号:

文献标识码:

文章编号:

Prediction of the Harvester Machinery Clinching Joints for Mechanical Properties Based on Improved BP Neural Network

Mudanjiang Normal University, Mudanjiang

China

Abstract



图 1 收割机

Fig.1 Harvester machinery




图 2 铆接接头

Fig.2 Clinching joint




图 3 铆接接头成型过程

Fig.3 Process of forming clinching joint

在开始对学习比率和动量进行讨论以前首先需要测量 $\Delta E(n)$ 与 $E(n)$ 之间的大小关系，这里我们定义关系系数：

$$e_r(n): e_r(n) = \frac{\Delta E(n)}{E(n)} = \frac{E(n) - E(n-1)}{E(n)}$$

通过以上公式关系我们可以对学习比率和动量进行分别定义，

() $e_r(n) < 0$ 时

$$\eta(n+1) = \eta(n) \left[+u \mathcal{E}^{-e_r(n)} \right] \quad u \in ()$$

$$\zeta(n+1) = \zeta(n) \left[+u \mathcal{E}^{-e_r(n)} \right] \quad v \in ()$$

() $e_r(n) \geq 0$ 时

$$\eta(n+1) = \eta(n) \left[-u \mathcal{E}^{-e_r(n)} \right] \quad u \in ()$$

$$\zeta(n+1) = \zeta(n) \left[u \mathcal{E}^{-e_r(n)} \right] \quad v \in ()$$

式中： n 表示迭代次数， η 表示学习比率， ζ 表示动量系数。

2.2 BP-ALM算法

根据 定理，一个三层 网络即可完成任意 维空间到 维空间的映射，如图 所示。整个网络结构包括输入节点、中间节点和输出节点组成， 公式被引入中间层和输出层 。




图 4 BP-ALM的冲铆预测模型

Fig.4 BP-ALM prediction models of clinching joint

模型均方差由下式定义：

$$E_p = - \sum_{j=1}^N (y_{pj} - o_{pj})$$

式中： y_{pj} 预期输出节点值 o_{pj} 实际输出节点值。

为了提出新的模型这里使用 公式：

$$O_{pj} = f(\text{net}_{pj}) = \frac{1}{1 + e^{-\text{net}_{pj} + q_j}}$$

$$\text{net}_{pj} = \sum_l w_{jl} O_{pl}$$

$$f'(\text{net}_{pj}) = \frac{\partial O_{pj}}{\partial \text{net}_{pj}} = \frac{\partial}{\partial \text{net}_{pj}} \left[\frac{1}{1 + e^{-\text{net}_{pj} + q_j}} \right] = O_{pj} (1 - O_{pj})$$

$$\Delta w_{ji}(n+1) = \eta_j d_{pj} O_{pi} + \xi_j \Delta w_{ji}(n)$$

$$\Delta q_{ji}(n+1) = \sum \eta_j d_{pj} + \xi_j \Delta q_{ji}(n)$$

式中： d_{pj} 参考了 层节点 的误差信号，而 O_{pi} 参考了 () 层输出节点 信号。

对此，整体的算法过程如下所示：

第一步：在区间 之间随机选取 w_{ji} ， w_{kj} ， q_j ， q_k 的初始值。

第二步：将初始向量 x_p 施加于输入节点。

第三步：计算网络节点输入中间层节点值和中间层 节点输出值： $O_{pk} = f(\sum w_{kj} O_{pj} + q_k)$

第四步：移动至 层，计算输出值： $O_{pk} = f(\sum w_{kj} O_{pj} + q_k)$

第五步，对输出节点计算误差： $d_{pk} = O_{pk}(-O_{pk})(y_{pk} - O_{pk})$

第六步，对中间层节点计算误差： $d_{pj} = O_{pj}(-O_{pj})\left(\sum_{k=1}^n w_{kj} d_{pk}\right)$

第七步，更新输出层的权值和偏差：

$$\left. \begin{aligned} \Delta w_{ki}(n+1) &= -\eta_k \frac{\partial E_p}{\partial w_{kj}} + \xi_k \Delta w_{kj}(n) = \sum_{p=1}^P (\eta_k d_{pk} O_j) + \xi_k \Delta w_{kj}(n) \\ \Delta q_k(n+1) &= \sum_{p=1}^P \eta_k d_{pk} + \xi_k \Delta q_k(n) \end{aligned} \right\}$$

第八步，更新中间层的权值和偏差：

$$\left. \begin{aligned} \Delta w_{ji}(n+1) &= -\eta_j \frac{\partial E_p}{\partial w_{ji}} + \xi_j \Delta w_{ji}(n) = \sum_{p=1}^P (\eta_j d_{pj} x_i) + \xi_j \Delta w_{ji}(n) \\ \Delta q_j(n+1) &= \sum_{p=1}^P \eta_j d_{pj} + \xi_j \Delta q_j(n) \end{aligned} \right\}$$

第九步，回到第二步重复进行操作，直到总体误差足够小，计算终止。

3 收割机铆接接头模型验证与分析

针对铆接接头机理特性，通过 算法进行计算分析后得到程序计算结果，训练次数为 ，总的均方根误差如图 所示。由图 可知，随着训练次数的增加，平均总均方误差和最小总均方误差都先减小后基本保持不变，且训练完之后平均总均方误差与最小总均方误差相等。图 为 网络训练误差曲线，由图 可以看出，经过 次训练以后， 的训练目标误差为 $err_goal = \times^{-}$ ，运行时间为 。传统的 算法的预测模型在训练目标误差为 $err_goal = \times^{-}$ 的条件下，训练次数为 ，运行时间为 。改进 混合算法不仅比传统的 算法训练次数少，而且预测精度高。




图 5 次数与均方差曲线

Fig.5 Curve of number and mean square error




图 6 BP 网络训练误差曲线

Fig.6 Curve of BP network training error

表 为传统与改进 神经网络预测值与预测误差，由表 可知，传统 神经网络对铆接接头剪切力强度预测最大值误差为 %，最小误差为 %；对铆接接头剥离力强度预测最大值误差为 %，最小误差为 %。而改进 神经网络对铆接接头剪切力强度预测最大值误差为 %，最小误差为 %；对铆接接头剥离力强度预测最大值误差为 %，最小误差为 %。对比 预测模型，针对材料自身剪切力与剥离力强度预测与测试结果的相对误差。通过

算法的预测模型在计算的稳定性和精确性要比传统 算法具有优势。剪切强度最大相对误差从 % 下降到 %，剥离强度相对误差从 % 下降到 %，误差分布趋于合理，误差数值较小。

表 1 传统与改进 BP 神经网络预测值与预测误差

Tab.1 Traditional and improved BP neural network prediction value and prediction error

| 实测剪切 样本 | 传统预测 力强度 | 改进预测 剪切力强 度 | 传统预测 剪切力强 度误差 | 改进预测 剪切力强 度误差 | 实测剥 离力强 度 | 传统预测 剥离力强 度 | 改进预测 剥离力强 度 | 传统预测 剥离力强 度误差 | 改进预测 剥离力强 度误差 |
|------------|-------------|-------------------|---------------------|---------------------|-----------------|-------------------|-------------------|---------------------|---------------------|
|------------|-------------|-------------------|---------------------|---------------------|-----------------|-------------------|-------------------|---------------------|---------------------|

4 结 论

() 针对铆接头力学性能的，接受样本训练后的 混合预测模型，在考虑钣金件厚度、硬度以及接头底部直径等参数后，能够在一定训练数范围中能够正确的预测其力学性能。

() 神经网络预测模型相对标准 神经网络预测模型收敛时间较短，较稳定，预测精度较高。

() 通过 算法的预测模型在计算的稳定性和精确性要比传统 算法具有优势。剪切强度最大相对误差从 % 下降到 %，剥离强度相对误差从 % 下降到 %，误差分布趋于合理，误差数值较小。

() 训练后的 神经网络预测模型的预测精度和泛化能力能够满足工程需要，能够对后期的钢铝铆接头进行优化设计提供理论依据。

参考文献

- 李耀明 叶晓飞 徐立章 等 联合收割机行走半轴载荷测试系统构建与性能试验 农业工程学报
 张成涛 谭 彧 吴 刚 等 谷物联合收割机电控全液压转向系统建模与仿真 农业工程学报
 石 玕 樊 丁 陈剑虹 基于神经网络方法的焊接接头力学性能预测 焊接学报
 张艳飞 董俊慧 张永志 基于自适应模糊神经网络焊接接头力学性能预测 焊接学报
 龙江启 兰凤崇 陈吉清 等 基于神经网络无铆钉自冲铆接头力学性能预测 计算机集成制造系统